

DOI:10.3969/j.issn.1001-4551.2022.11.020

基于改进 LVQ 算法的塔式起重机运行状态检验^{*}

周庆辉^{1,2}, 刘浩世¹, 刘耀飞^{1,3}, 李欣^{1,2}, 谢贻东^{1,2}

(1. 北京建筑大学 机电与车辆工程学院, 北京 100044; 2. 北京市建筑安全监测工程技术研究中心,
北京 100044; 3. 中铁建设集团有限公司, 北京 100040)

摘要:为了提高起重机运行安全检验结果的准确性,避免误判,并且提高塔式起重机检验的智能化水平,提出了一种基于改进的学习矢量量化(LVQ)人工神经网络模型,实现了对塔式起重机运行安全状态的智能检验。首先,根据近年来建筑工地塔式起重机的检验数据,建立了样本集,基于塔式起重机相关的安全技术标准和规范,将检验项目分解为最常见、最主要的15个因素,作为神经网络输入层的数目;然后,对290台塔式起重机的检验数据进行了统计(金属结构的连接、作业环境、主要零部件与机构,此3项不合格的频次较高);最后,在学习矢量量化(LVQ)算法基础上,改进了LVQ人工神经网络的检验评价模型,再运用优化的特征数据训练出了LVQ分类器,提出了改进的LVQ智能检验方法,对50个测试样本进行了分类识别实验。研究结果表明:改进后的LVQ人工神经网络算法提高了塔式起重机检验结果的正确率,在整机检验中合格率和不合格率均能达到100%,避免了误判,实现了对塔式起重机设备的安全智能检验。

关键词:自行式起重机;运行安全状态;安全技术标准和规范;学习矢量量化;人工神经网络模型;LVQ分类器

中图分类号:TH213.3; TU391

文献标识码:A

文章编号:1001-4551(2022)11-1636-07

Operation status inspection of tower crane based on improved LVQ algorithm

ZHOU Qing-hui^{1,2}, LIU Hao-shi¹, LIU Yao-fei^{1,3}, LI Xin^{1,2}, XIE Yi-dong^{1,2}

(1. School of Mechanical, Electrical and Vehicle Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China; 2. Beijing Construction Safety Monitoring Engineering Technology Research Center, Beijing 100044, China; 3. China Railway Construction Group Co., Ltd., Beijing 100040, China)

Abstract: In order to improve the accuracy of safe operation of tower crane inspection results, avoid misjudgment, and improve the intelligence level of tower crane inspection, an improved learning vector quantization (LVQ) artificial neural network model was proposed to realize the intelligent inspection of safe operation of tower crane. Firstly, the randomly-selected test samples set was established for the whole equipment on the basis of the inspection samples of tower cranes on construction sites in recent years. Based on the safety technical standards and specifications of tower cranes, the inspection items were divided into the 15 common factors as the number of input layer of the neural network in the sample set. Then, the inspection data of 290 tower cranes were counted. For the connection of metal structure, working environment, main parts and mechanisms, the frequency of these three nonconformities was high. Finally, the conventional LVQ algorithm was improved on the evaluation model, and the LVQ classifier was trained by using the optimized characteristic data. Hence, based on the improved LVQ algorithm, an intelligent inspection was proposed. The classification and recognition experiments were carried out on 50 test samples. The research result shows that the improved LVQ algorithm can increase the accuracy of judgment, because both the qualified rate for qualified equipment and unqualified rate for the unqualified equipment can all reach 100% in the whole equipment inspection. Therefore, the improved LVQ algorithm can avoid misjudgment and realize the safe and intelligent inspection.

Key words: self-propelled crane; operation safety status; safety technical standards and specifications; learning vector quantization (LVQ); artificial neural network model; LVQ classifier

收稿日期:2021-12-07

基金项目:国家自然科学基金青年科学基金项目(51905028);住房与城乡建设部科技计划项目(2022-K-079)

作者简介:周庆辉(1973-),男,山东济南人,博士,副教授,主要从事车辆智能控制技术方面的研究。E-mail:qhzhou@yeah.net

0 引言

塔式起重机是建筑工地上最常用的一种垂直运输起重设备, 属于特种设备, 因此, 有必要对其进行安装检验工作。对塔式起重机进行检验关系到其后续的安全运行, 因此, 需要严格按照相应的法律法规、标准规范进行检验^[1-3], 以确保设备的安全运行。

随着人工智能的发展, 无人机安全巡检、吊钩可视化系统、智能监控系统等技术运用到了塔式起重机检验检测环节当中。

安建民等人^[4]使用无人机对塔式起重机进行了检验, 利用图像和视频模式实时传输检验结果, 现场判断分析。周前飞等人^[5]使用无人机对大型起重机的金属结构进行了智能视觉检测, 利用数字图像处理技术, 进行了其缺陷特征的提取与识别。张彦庆等人^[6]研究设计了铁路集装箱正面起重机的安全监控系统, 实现了其数据监控、设备管理维护和运行轨迹回放等功能。张充等人^[7]将塔式起重机使用过程中的结构安全监测内容分为静力监测内容和动力监测内容, 利用理论分析的方式, 并结合实际的经验, 确定了关键参数测点的位置, 对塔式起重机进行了结构安全检测。

上述这些方法或系统可以完成对塔式起重机的侦查、拍照、监控等工作, 进行图像的识别和处理, 及时排查起重机的安全隐患, 避免事故的发生, 提高了塔式起重机检验、检测工作效率和质量。但是, 目前的检验、检测系统还不能完全代替人工检测, 因为存在误判的可能, 会给安全带来隐患。因此, 如何提高和改进诊断方法的准确率^[8], 提高其故障分类的效率, 降低误判的机率, 成为塔式起重机检测研究方面的重点。

笔者在学习矢量量化(LVQ)人工神经网络算法基础上, 通过改进检验评价模型, 运用优化的特征数据训练出 LVQ 分类器, 提高起重机检验结果的准确性, 避免误判, 为塔式起重机的健康评价提供理论指导。

1 LVQ 人工神经网络

机器学习是利用数据训练出模型, 然后使用模型进行预测的一种方法。基于实例的算法常根据决策问题建立模型, 先选取一批样本数据, 再根据某些近似性把新数据与样本数据进行比较, 寻找最佳匹配。

常见的机器学习算法包括:k-近邻算法(k-nearest neighbor, KNN)、学习矢量量化(LVQ)、以及自组织映

射算法(self-organizing map, SOM)^[9-11]。

1.1 LVQ 网络结构

LVQ 神经网络由 3 层神经元组成, 即输入层、竞争层和线性输出层。

输入层与竞争层之间采用全连接的方式, 竞争层与线性输出层之间采用部分连接的方式。竞争层神经元个数总是大于线性输出层神经元个数, 每个竞争层神经元只与一个线性输出层神经元相连接且连接权值恒为 1。但是, 每个线性输出层神经元可以与多个竞争层神经元相连接。竞争层神经元与线性输出层神经元的值只能是 1 或 0。当某个输入模式被送至网络时, 与输入模式距离最近的竞争层神经元被激活, 神经元的状态为“1”, 而其他竞争层神经元的状态均为“0”。因此, 与被激活神经元相连接的线性输出层神经元状态也为“1”, 而其他线性输出层神经元的状态均为“0”^[12]。

LVQ 神经网络结构如图 1 所示。

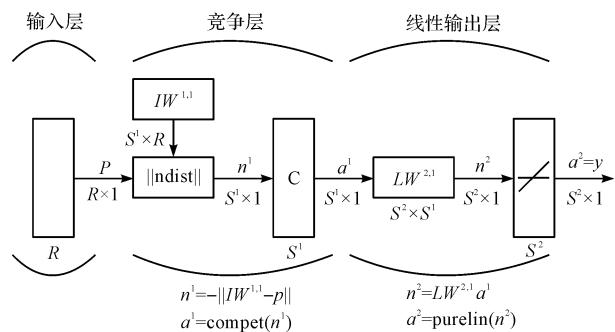


图 1 LVQ 神经网络结构

P — R 维的输入模式; S^1 —竞争层神经元个数; $IW^{1,1}$ —输入层与竞争层之间的连接权系数矩阵; n^1 —竞争层神经元的输入; a^1 —竞争层神经元的输出; $LW^{2,1}$ —竞争层与线性输出层之间的连接权系数矩阵; n^2 —线性输出层神经元的输入; a^2 —线性输出层神经元的输出

1.2 LVQ 网络原理与算法

设输入训练样本为 N 维向量 $X = (x_1, x_2, \dots, x_N)^T$, 可视为在 N 维空间的样本点, 而同一个类别的样本点可能散布成数群, 各有各的形心^[13]。

LVQ 神经网络通过样本点来估计各个群体的形心位置, 并正确地对应到所属的类别中; 训练完成后的应用阶段, 即可利用各自群体的形心位置, 做出正确的分类判断。

LVQ 网络的第 2 层是非监督的竞争层, 每个神经元为一个独立的子类别。当样本点输入竞争层中, 计算样本点与各子类别间的欧式距离, 寻找出最合适的子类别归属, 即:

$$\| \mathbf{X} - \mathbf{W}_c \| = \min_i \| \mathbf{X} - \mathbf{W}_i \| = \min_i \left\{ \sum_{j=1}^N \mathbf{x}_j - \mathbf{w}_j \right\}^Z \quad (1)$$

式中: i —样本点; \mathbf{X} —输入样本向量; \mathbf{W} —网络初始形心位置向量,即输入样本点*i*与子类别间的欧式距离; \mathbf{W}_c —竞争胜出后的子类别。

当*i=c*时,即分类结果正确,可得到公式为:

$$\mathbf{W}_c(n+1) = \mathbf{W}_c(n) + \eta(n)[\mathbf{X}(n) - \mathbf{W}_c(n)] \quad (2)$$

式中: η —学习率,数值介于0~1之间,具有抑制网络权值趋近无限大的作用。

当*i≠c*时,即分类结果错误,可得到公式:

$$\mathbf{W}_c(n+1) = \mathbf{W}_c(n) - \eta(n)[\mathbf{X}(n) - \mathbf{W}_c(n)] \quad (3)$$

2 塔式起重机检验主要内容

依照GB/T 6067.1—2010《起重机械安全规程.第1部分:总则》、GB/T 5031—2019《塔式起重机》、TSG Q7016—2016《起重机械安装改造重大修理监督检验规则》、TSG Q7015—2016《起重机械定期检验规则》、JGJ 305—2013《建筑施工升降设备设施检验标准》、DB11/611—2008《施工现场塔式起重机检验规则》以及塔式起重机安全管理相关安全技术标准和规范,笔者整理归纳出了塔式起重机检验主要内容,如图2所示。

该处笔者以2018年某市检验了的290台塔式起重机为例,统计了不合格项目,其中,前10项如表1所示。

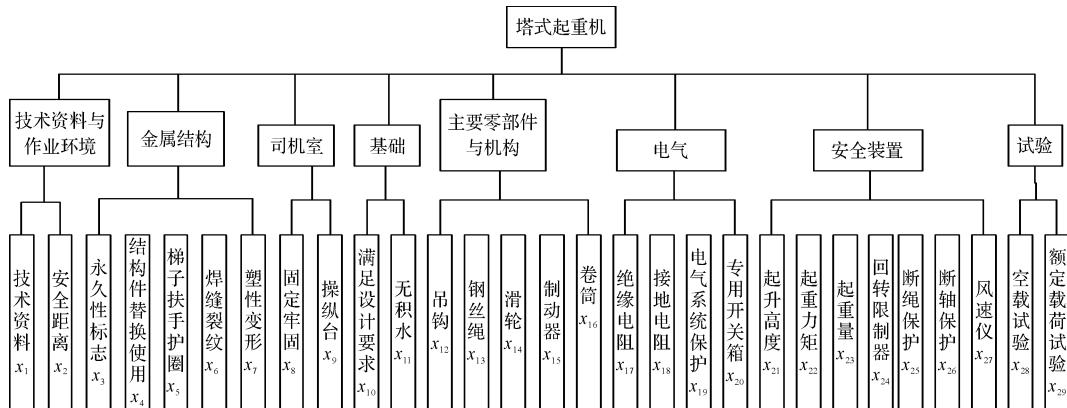


图2 塔式起重机检验主要内容

表1 不合格项目表

序号	不合格项目	次数
1	金属结构:金属结构的连接焊缝无明显可见的裂纹等缺陷;螺栓和销轴连接应符合塔式起重机使用说明书的要求	27
2	作业环境:两台塔式起重机之间的最小架设距离应保证处于低位的塔式起重机的臂架端部与另一台塔式起重机的塔身之间不小于2m的距离;处于高位塔式起重机的最低位置的部件与低位塔式起重机处于最高位置部件之间的垂直距离不小2m	24
3	主要零部件与机构:应有防止钢丝绳脱槽的装置,且可靠有效	16
4	金属结构:对附着式塔式起重机,附着装置与塔身节或建筑物的连接必须安全可靠,连接件不应缺少或松动,并符合说明书要求	11
5	金属结构:塔式起重机的主要受力构件不应有塑性变形、严重锈蚀(或腐蚀)和可见裂纹	9
6	安全装置:塔式起重机应安装起重力矩限制器,并符合要求	6
7	电气控制:塔式起重机必须设置非自动复位的、能切断塔式起重机总控制电源的紧急断电开关,该开关应设在司机操作方便的地方	6
8	电气控制:塔式起重机供电电源应设总电源开关,该开关应设置在靠近塔式起重机且地面人员易于操作的地方,开关出线端不得连接与塔式起重机无关的电气设备	6
9	安全装置:小车变幅的塔式起重机,变幅的双向均应设置断绳保护装置,并符合要求	5
10	金属结构:塔式起重机安装后,在空载、风速小于3m/s的状态下,塔身轴心线对支承面的侧向垂直度≤4/1000,附着时,最高附着点以下塔身轴心线对支承面侧向垂直度应≤2/1000	3

从表1可以看出:金属结构的连接、作业环境以及

主要零部件与机构是主要问题项,出现的频次较高。

3 LVQ 网络在检验中的应用

3.1 样本集的构建

样本集构建是 LVQ 神经网络在塔式起重机检验中的重点内容。样本集中的特征选取要科学、合理,满足实际需要。

样本集如表 2 所示。

表 2 样本数据集

序号	整机 检验	x_1	x_2	x_6	x_7	…	x_{14}	x_{15}
1	1	1	1	1	1		1	1
2	1	1	1	1	1		0	1
3	2	0	1	0	1		1	1
4	2	1	0	1	1		0	0
...								
348	1	1	1	1	1		1	0
349	2	1	1	1	0		0	0
350	1	1	1	1	0		0	1

在表 2 中,笔者选取了最常见、最主要的 15 个因素为主要检测对象,根据塔式起重机的实际运行状态,构成了样本空间。

单项检测结果主要分为合格与不合格,合格用 1 表示,不合格则用 0 表示。在表 2 中的“整机检验”一列中,1 表示整机合格,2 表示整机不合格。

从 2018—2020 年北京市建筑工地塔式起重机的检验样本中,笔者随机抽取了 350 个原始数据,构建了样本数据集,其中,检验结论合格的 226 台,不合格的 124 台。

在 350 个样本数据集中,笔者随机抽取 300 个作为训练集,剩余 50 个作为测试集,具体构成如表 3 所示。

表 3 样本数据分配表

类别	训练集	测试集	汇总
整机合格数	194	32	226
整机不合格数	106	18	124
整机数量	300	50	350

3.2 样本训练参数的选择

神经网络的学习过程是离线进行的,识别系统只需要得到自动更新学习之后的权值数量和输出神经元的数量。笔者使用多维特征信号对神经网络进行训练。

由于输入层为 15 组不同的特征信号,识别目标为 2 种不同的检验类别;所以笔者确定 LVQ 神经网络结构为 15-10-2 型,输入层神经元数为 15,竞争层神经元

数为 10,输出层神经元数为 2。具体参数初始设置为:学习率 0.1,窗口参数 0.25,显示频率设置为 10,训练目标最小精度设为 0.1,迭代次数选择为 1 000。以上参数是在经验基础上反复测试得来的。

3.3 网络测试仿真

在测试神经网络时,可以利用仿真的方式,对输出的数值进行处理。MATLAB 的 LVQ 神经网络仿真,可以通过函数曲线,分析实际输出值和预期输出值之间的误差。如果误差较小,可以证明塔式起重机的检测结果与目标输出几乎是一样的,从而准确地反映出塔式起重机的检验情况。

3.4 改进 LVQ 神经网络分类器

3.4.1 熵值法计算权值,优化特征信号

塔式起重机检验是属于两类模式(合格、不合格)分类问题。输入是一个 N 维向量下 $\mathbf{X} = (x_1, x_2, \dots, x_N)^T$,其中,每一个分量都对应一个权值 ω_i ,隐含层的输出叠加为一个标量值 v :

$$v = \sum_{i=1}^N x_i w_i \quad (4)$$

式中: v —标量值; x_i —输入分量; w_i —权值。

随后,在二值阈值元件中得到的标量值 v 进行判断,产生二值输出:

$$y = \begin{cases} 1 & v \geq 0 \\ 2 & v < 0 \end{cases} \quad (5)$$

式中: y —输出值。

LVQ 神经网络分类器可以将输入数据分为两类:合格或不合格。当 $y = 1$ 时,认为输入 \mathbf{X} 属于合格类;当 $y = 2$ 时,认为输入 \mathbf{X} 属于不合格类。

根据式(4)可知:权值的大小,影响分类的正确与否。同时,塔式起重机权值还与故障率、事故等级、事故类型有关。通过对故障和事故发生的各影响因素的分析,推演故障和事故发生过程,解析因果关系^[14],找出主次要因素,进一步调整设置权值。

权值 ω_i 的确定可以根据表 2 中样本故障数据,采用熵值法进行计算,得到的 15 个因素的权值。

权值的设置如图 3 所示。

此外,输入向量 \mathbf{X} ,群体的形心位置 \mathbf{W} 对输出结果也有影响。

笔者将输入向量 $\mathbf{X} = (x_1, x_2, \dots, x_N)^T$ 送入到输入层,并计算竞争层神经元与输入向量的欧式距离 d_i :

$$d_i = \sqrt{\sum_{j=1}^N (x_j - w_{ij})^2} \quad i = 1, 2, \dots, N \quad (6)$$

式中: d_i —欧式距离; x_j —第 j 列输入分量; w_{ij} —第 i 行,

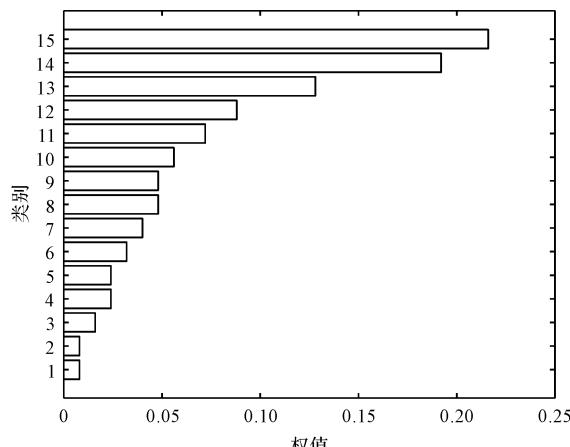


图 3 权值的设置

j 列的形心位置。

欧式距离 d_i 对 LVQ 分类具有重要的影响。对于样本点,如果计算出的欧式距离不符合实际情况,就不能得到正确的分类^[15]。因此,在塔式起重机检验工程实践中,优化输入向量 \mathbf{X} 的特征信号,得到正确的样本点分布,对于分类结果的准确性也是至关重要的。

3.4.2 学习率的调整

LVQ 算法中,学习率是个很重要的参数,会影响分类结果。当学习率取大值时,就趋向于判断为合格。当学习率取小值时,就会趋向于判断为不合格。在定义学习率时,要考虑收敛的速度和算法的稳定性。

最大学习率满足下式^[16]:

$$0 < \eta < \frac{2}{\lambda_{\max}} \quad (7)$$

式中: λ_{\max} —输入向量 \mathbf{X} 组成的自相关矩阵 \mathbf{R} 的最大特征值, λ_{\max} 一般不可知,通常使用自相关矩阵 \mathbf{R} 的迹来代替。

按定义,矩阵的迹 $tr(\mathbf{R})$ 是矩阵主对角线元素之和:

$$tr(\mathbf{R}) = \sum \mathbf{R}(i, i) \quad (8)$$

式中: $tr(\mathbf{R})$ —矩阵的迹; \mathbf{R} —自相关矩阵。

3.4.3 隐含层节点数的调整

隐含层节点数对人工神经网络预测精度也有很大的影响:节点数太少,网络不能很好地学习,需要增加训练次数,训练的精度也受影响;节点数太多,训练时间增加,网络容易过拟合。

隐含层节点数满足下列经验公式^[17]:

$$l < \sqrt{(m + n)} + a \quad (9)$$

式中: l —隐含层节点数; m —输出层节点数; n —输入层节点数; a —0~10 之间的常数。

最佳的隐含层节点数选择,首先要用式(9)确定节点数的大致范围,然后用试凑法确定最佳的节点数。

对于塔式起重机检验问题而言,当隐含层节点数减小时,合格率误差会升高,不合格率会降低;当隐含层节点数增加时,合格率误差会降低,不合格率会升高;当隐含层节点数为 7 时,合格率和不合格率的误差值均为最小,可以达到 0。

3.4.4 改进 LVQ 算法流程

塔式起重机检验存在数据量大、重复率高的问题,若直接用于目标识别,不仅增大计算量,还会造成识别准确率降低。为了实现零误判,运用优化的特征数据训练 LVQ 分类器,改进设计训练集。

改进 LVQ 算法检验分类流程如图 4 所示。

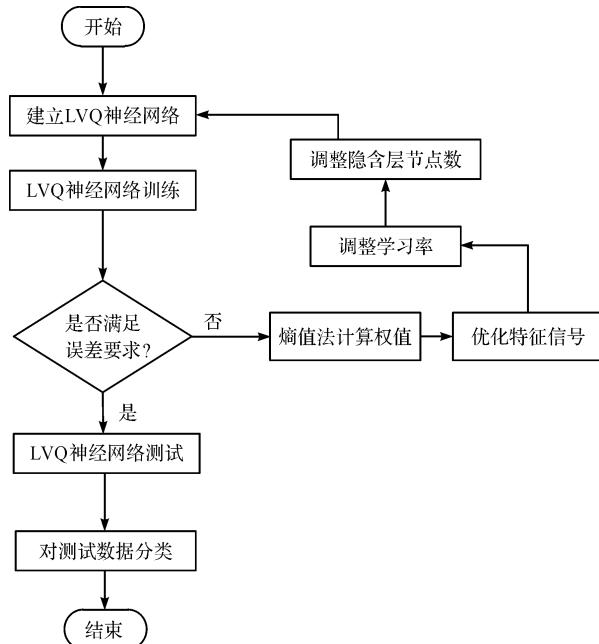


图 4 改进 LVQ 算法流程

根据检验工程情况,首先,笔者在 300 个训练集中优选出特征数据,找出典型样本作为训练集,避免出现重复交叉,如“塔身垂直度”问题或“安全距离”问题,单独出现在训练样本里,而不是两个问题同时存在样本里;

其次,按照特征数据,简化维度,把 15 个检验项目,按照 DB11/611—2008《施工现场塔式起重机检验规则》中所规定的关键词和一般项进行分类,分为两个维度;

最后,运用优化的特征数据训练 LVQ 分类器,得到最佳神经元数目和学习率,即提高了人工神经网络训练速度,节省了计算时间,又提高了学习效果,保证了检验的准确率。

4 实验结果与分析

笔者将测试集的 50 个样本数据输入训练好的

LVQ 网络,利用通过训练得到的分类特征权值对 50 个测试样本进行识别分类。

LVQ 改进前后样本测试图对比如图 5 所示。

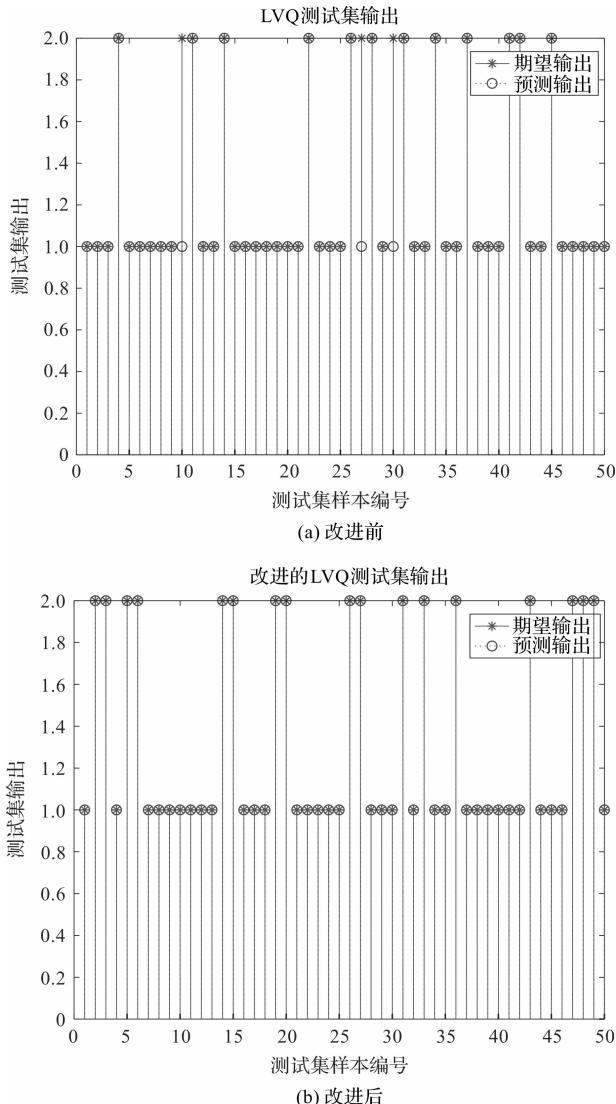


图 5 LVQ 改进前后样本测试图

LVQ 改进前后误差比较对比如图 6 所示。

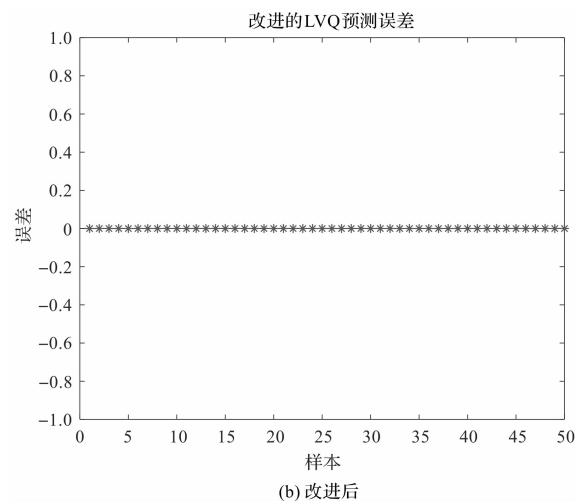
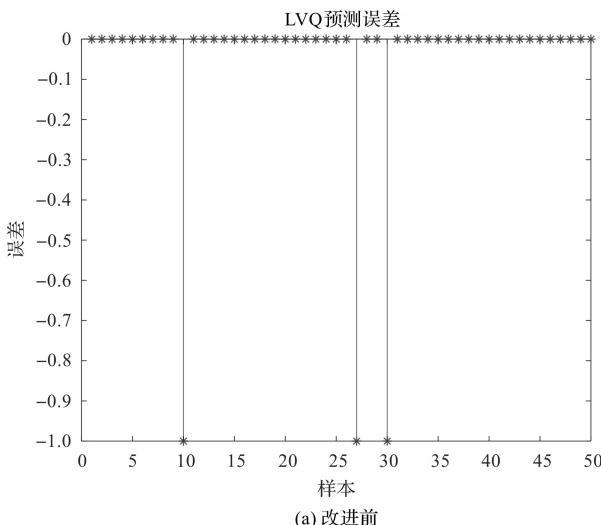


图 6 LVQ 改进前后误差比较

由图 5(a)、图 6(a)可知:测试集中第 10、27、30 这 3 个样本是不合格设备,但是被误判为了合格设备。在实际设备检验中,该情况会是不允许发生的,因为它降低了检验的安全性,存在安全隐患。

而改进后的 LVQ 算法中,运用了优化的特征数据训练 LVQ 分类器,通过优化设计样本训练集,优化学习率和神经元数目,对整机检验的合格率和不合格率均能达到 100%,避免了误判,提高了检验效果。

特征优化前后 LVQ 检验情况对比如表 4 所示。

表 4 特征优化前后 LVQ 检验情况对比

优化特征/单位	前	后
向量维数/个	15	2
测试样本数目/个	50	50
合格率/%	100	100
不合格率/%	78.57	100

在特征优化前的 LVQ 算法中,对合格设备检测,其合格率达 100%;对不合格设备检测,其不合格率达 78.57%,存在“将不合格的设备误判为合格”的问题。

通过优化特征,改进 LVQ 神经网络分类器,向量维度分为关键项和一般项两个,检验结果完全满足实际需要。对合格设备而言,其检验合格率达到了 100%;对不合格设备而言,其检验不合格率也达到了 100%,避免了误判。

利用 3 种不同的方法检验塔式起重机所得结果如表 5 所示。

表 5 3 种检验方法对比表

主要检验方法	人工检验	优化前的 LVQ	改进后的 LVQ
自动判断	否	是	是
训练过程	人眼	无师训练	无师训练
是否存在误判	否	是	否
有无主观因素	有	无	无

从表 5 中可以看出:在塔式起重机检验中,与改进前的 LVQ 相比,改进后的 LVQ 和人工检验都不会存在误判,但人工检测需要长时间的检验识别(很可能由于疲劳等主观因素造成失误),而用机器学习代替人工检验,可以解决人为因素所带来的诸多影响,很好地实现智能检测。

5 结束语

为了提高起重机运行安全检验结果的准确性和智能化水平,笔者提出了一种基于改进的学习矢量量化(LVQ)人工神经网络模型,实现了对塔式起重机运行安全状态的智能检验。

首先,笔者根据近年来建筑工地塔式起重机的检验数据,建立了其样本集,利用熵值法计算了其权值,优化了特征信号,调整了学习率,调整了隐含层节点数,得到了改进的 LVQ 神经网络分类器;建立了改进的 LVQ 人工神经网络模型,在样本集中进行了人工神经网络训练,实现了对塔式起重机运行安全状态的智能检验。

研究结果表明:

(1)根据近年塔式起重机检验数据统计,检验项目中金属结构的连接、作业环境、主要零部件与机构出现不合格的频次较高;

(2)通过优化特征信号,调整学习率,调整隐含层节点数改进了 LVQ 算法,利用熵值法计算权值,优化输入向量 X 的特征信号,得到了塔式起重机检验正确的样本点分布;按照输入向量自相关矩阵 R 的最大特征值计算出最大学习率;调整隐含层节点数,得到最佳值,当隐含层节点数为 7 时,合格率和不合格率的误差值均为最小;

(3)在整机检验中改进 LVQ 算法,避免了误判,实现了塔式起重机机器学习的智能检验;虽然优化前的 LVQ 算法对合格设备检验能达到 100%,但对不合格设备的判断率仅达 78.57%,依然存在误判,存在安全隐患;改进 LVQ 算法对合格设备检验的合格率可达 100%,对不合格设备检验的不合格率也可达 100%。

塔式起重机智能化检验是未来的发展方向,人工神经网络算法也将得到进一步发展。因此,在后续的研究中,笔者将会对这些算法的准确度和计算效率进行比较,以找到其中最优的算法。

本文引用格式:

周庆辉,刘浩世,刘耀飞,等.基于改进 LVQ 算法的塔式起重机运行状态检验[J].机电工程,2022,39(11):1636-1642.

ZHOU Qing-hui, LIU Hao-shi, LIU Yao-fei, et al. Operation status inspection of tower crane based on improved LVQ algorithm[J]. Journal of Mechanical & Electrical Engineering, 2022, 39(11): 1636-1642.

参考文献(References):

- [1] GB/T 6067.1—2010,《起重机械安全规程. 第 1 部分: 总则》[S].
- [2] GB/T 5031—2019,《塔式起重机》[S].
- [3] DB 11/611—2008,《施工现场塔式起重机检验规则》[S].
- [4] 安建民,郝 兵,郭伟伟,等. 基于无人机在塔机检验中的应用与研究[J]. 中国特种设备安全, 2020, 36(10): 23-26.
- [5] 周前飞,丁树庆,冯月贵,等. 大型起重机金属结构无人机智能视觉检测系统研究[J]. 内燃机配件, 2018(19): 224-228.
- [6] 张彦庆,张向东. 集装箱正面起重机安全监控系统[J]. 起重运输机械, 2021, (21): 56-60.
- [7] 张 充,赵挺生,蒋 灵,等. 塔式起重机结构安全监测参数选取及测点布置[J]. 中国安全科学学报, 2021, 31(8): 112-118.
- [8] 王 莹,王亚慧,安 允. 基于 PSO-KPCA-LVQ 的燃气调压器故障诊断[J]. 现代电子技术, 2020, 43(24): 67-71.
- [9] ZHANG Xiang-yu, AN Feng-wei, CHEN Lei, etc., A modular and reconfigurable pipeline architecture for learning vector quantization [J]. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2018, 65 (10): 3312-3325.
- [10] BRINKROLF J, GOPFERT C, HAMMER B. Differential privacy for learning vector quantization [J]. *Neurocomputing*, 2019, 342: 125-136.
- [11] 宋亮亮,杨 穗,范栋琛,等. 基于改进学习矢量量化神经网络输电线路故障识别技术[J]. 科学技术与工程, 2021, 21(2): 583-590.
- [12] 欧阳城添,袁 瑾. 基于学习矢量量化的空调压缩机声纹诊断方法[J]. 计算机工程与设计, 2021, 42(9): 2634-2641.
- [13] PETRA S, MICHAEL B, BARBARA H. Adaptive relevance matrices in learning vector quantization [J]. *Neural Computation*, 2009, 21(12): 3532-3561.
- [14] 张建荣,张 伟,薛楠楠,等. 基于随机森林算法的塔式起重机安全事故预测及致因分析[J]. 安全与环境工程, 2021, 28(5): 36-42.
- [15] WEN Shi-ping, XIAO Shui-xin, YAN Zheng, et al. Adjusting learning rate of memristor-based multilayer neural networks via fuzzy method [J]. *IEEE Transactions on Computer Aided Design of Integrated Circuits and Systems*, 2019, 38(6): 1084-1094.
- [16] 陈 明. MATLAB 神经网络原理与实例精解[M]. 北京: 清华大学出版社, 2013.
- [17] 高宗帅,郗 涛,徐伟雄,等. 基于改进遗传算法-反向传播神经网络的升降机健康评价研究[J]. 机电工程, 2021, 38(3): 314-319.

[编辑:司红岩]